

**SVEUČILIŠTE U ZAGREBU
FAKULTET PROMETNIH ZNANOSTI**

Izidor Oremović

**MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE
ZA ODREĐIVANJE PRODULJENJA VREMENA
POJEDINE FAZE KOD SEMAFORIZIRANIH
RASKRIŽJA**

ZAVRŠNI RAD

Zagreb, 2018.

Zagreb, 30. ožujka 2018.

Zavod: **Zavod za inteligentne transportne sustave**
Predmet: **Automatsko upravljanje u prometu i transportu**

ZAVRŠNI ZADATAK br. 4796

Pristupnik: **Izidor Oremović (0135237973)**
Studij: **Inteligentni transportni sustavi i logistika**
Smjer: **Inteligentni transportni sustavi**

Zadatak: **Mogućnosti primjene neizrazite logike za određivanje produljenja vremena pojedine faze kod semaforiziranih raskrižja**

Opis zadatka:

Kako bi se postigla bolja razina uslužnosti semaforiziranog raskrižja moguće je primijeniti neizrazitu logiku u svrhu skraćanja odnosno produljenja trajanja pojedine faze ovisno o trenutnom stanju na privozima raskrižja. U radu je potrebno opisati problem skraćanja odnosno produljenja trajanja faze, objasniti principe rada neizrazite logike, prikazati vezu između simulacijskog alata PTV VISSIM i MATLAB-a te izraditi algoritam za promjenu vremena trajanje pojedine faze zasnovan na neizrazitoj logici.

Mentor:

Predsjednik povjerenstva za
završni ispit:

izv. prof. dr. sc. Edouard Ivanjko

Sveučilište u Zagrebu
Fakultet prometnih znanosti

ZAVRŠNI RAD

**MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE
ZA ODREĐIVANJE PRODULJENJA VREMENA
POJEDINE FAZE KOD SEMAFORIZIRANIH
RASKRIŽJA**

**POSSIBILITY OF APPLYING FUZZY LOGIC FOR
EXTENDING PHASE TIME FOR SIGNALIZED
INTERSECTIONS**

Mentor: izv. prof. dr. sc. Edouard Ivanjko Student: Izidor Oremović
JMBAG: 0135237973

Zagreb, rujan 2018.

Sažetak

Naslov: Mogućnosti primjene neizrazite logike za određivanje produljenja vremena pojedine faze kod semaforiziranih raskrižja

Zbog stalnog razvoja društva i rasta gradova količina prometa u gradu prelazi iznose prometne potražnje za koje je planirana prometna infrastruktura. Nemogućnost stvarno-vremenskog odziva fiksnog upravljanja semaforiziranim raskrižjima na povećanje prometne potražnje pridodaje nastanku zagušenja i ostalim negativnim posljedicama koje ono donosi. Jedno od mogućih rješenje koje dolazi iz područja Inteligentnih Transportnih Sustava (ITS), je promjena trajanja vremena pojedinih signalnih faza. U ovom završnom radu opisane su dvije metode promjene trajanja faze zasnovane na neizrazitoj logici. Prva metoda produljuje trajanje pojedine faze na njenom početku dok druga tijekom izvođenja faze određuje za koliko je potrebno produljiti fazu. U svrhu usporedbe kvalitete rada predloženih metoda s fiksnim upravljanjem napravljen je model dvofaznog raskrižja u VISSIM-u te povezan s MATLAB-om radi izvođenja simulacija primjenom tri različita scenarija prometne potražnje. Rezultati emisija štetnih plinova su također analizirani, koristeći programski paket EnViVer. Dobiveni simulacijski rezultati pokazuju da je primjenom neizrazite logike moguće smanjiti količinu zagušenja koje nastajete na semaforiziranim raskrižjima korištenjem fiksnog upravljanja.

Ključne riječi: promjenjivo trajanja faze; inteligentni transportni sustavi; adaptivno upravljanje; simulacije u prometu; cestovna telematika

Abstract

Title: Possibility of Applying Fuzzy Logic for Extending Phase Time for Signalized Intersections

Due to the constant development of society and urban growth, the amount of traffic in cities is exceeding the planned amount for which the traffic infrastructure was built. Unresponsiveness of fixed-time control over signalized intersections to the increasing traffic demand brings in to the onset of congestion and other negative consequences that come with it. One possible solution which comes from the domain of Intelligent Transport Systems (ITS) is extending the signal phase time. Two methods of extending phase time with the use of fuzzy logic are described in this bachelor's thesis. The first method extends phase time at the begging of a phase and the second method extends phase time while the phase is ongoing. To compare the two methods with pretimed signal control, a two-phase intersection is modeled in VISSIM and connected with MATLAB to run the simulations constituting of three different traffic demand scenarios. Analysis of emitted harmful fumes is done using the EnViVer application. Attained simulation results show that it is possible to reduce the amount of traffic congestion which appears as a result of using the pretimed signal control on signalized intersections.

Keywords: variable phase time; intelligent transport systems; adaptive control; traffic simulations; road telematics

Sadržaj

1	Uvod	1
2	Problem upravljanja semaforiziranim raskrižjima	3
2.1	Razine upravljanja prometom	3
2.2	Strategije upravljanja semaforiziranim raskrižjima	5
2.2.1	Fiksno upravljanje	5
2.2.2	Prometno ovisno upravljanje	6
2.2.3	Adaptivno upravljanje	6
2.3	Metode za promjenu trajanja signalnih faza	7
3	Neizrazita logika i njena primjena u upravljanju semaforiziranim raskri- žjima	10
3.1	Neizrazita logika	10
3.2	Pregled postojećih rješenja	12
4	Neizraziti sustav za produljenje vremena trajanja faze	14
4.1	Metoda odlučivanja na početku faze	17
4.2	Metoda kontinuiranog odlučivanja	18
5	Simulacijsko okruženje PTV VISSIM/MATLAB	20
5.1	MATLAB	21
5.2	VISSIM	22
5.3	Povezivanje MATLAB-a i VISSIM-a	23
5.4	EnViVer	23
6	Simulacijski rezultati	24
6.1	Model i postavke	24
6.2	Opis prometnih scenarija	25
6.3	Prikaz i analiza rezultata	26
6.3.1	Rezultati prvog scenarija	26

6.3.2	Rezultati drugog scenarija	30
6.3.3	Rezultati trećeg scenarija	33
6.3.4	Analiza rezultata	37
7	Zaključak	39
	Literatura	42
	Popis slika	43
	Popis tablica	44
	Popis grafikona	45

1 Uvod

Dnevne migracije stanovnika urbanih područja poput odlaska na posao ili u školu uzrokuju svakodnevne značajne promjene prometne potražnje. U kombinaciji s konstantnim rastom gradova, operativni kapacitet prometnica u gradu je narušen. Prometna zagušenja nastala kao posljedice dnevnih migracija često nije moguće riješiti tek izgradnjom dodatnih prometnih traka. Razlog je što takvi građevinski pothvati često nisu dopušteni zbog nedostatka prostora u urbanim sredinama, a ponekad nisu ni isplativi. Dio prometnih zagušenja nastaje i kao posljedica lošeg upravljanja prometom. Osim uzrokovanja kašnjenja i povećanog stresa, loše upravljanje prometom uzrokuje i povećane emisije štetnih ispušnih plinova koji predstavljaju konstantnu prijetnju zdravlju građana [1] [2].

Semaforizirana raskrižja, kao čvorišta prometnih tokova, su aktivni entitet prometne mreže nad kojim postoji mogućnost upravljanja u svakom trenutku. Ustaljenim, odnosno fiksnim signalnim planovima, koji se najčešće koriste u Republici Hrvatskoj, rad semaforiziranih raskrižja ograničava se na tek nekoliko, a često i na samo jedan način rada. U slučaju da postoji nekoliko načina rada, oni se uvijek mijenjaju po istom ustaljenom vremenskom rasporedu tijekom dana. Bez povremenog podešavanja tih signalnih planova, a na koncu i s podešavanjem, fiksno upravljanje semaforiziranim raskrižjima često ne reagira u skladu sa stvarnom prometnom potražnjom.

Jedan od odgovora na zahtjeve urbane populacije, uz minimalnu izmjenu postojeće prometne infrastrukture, nalazi se u inteligentnom upravljanju semaforiziranim raskrižjima. Optimizacijom rada signalnih planova raskrižja moguće je smanjiti negativne utjecaje zagušenja. Na mreži raskrižja gdje se promet regulira neadaptivnim nekoordiniranim svjetlosnim signalima dolazi do nepotrebnih zaustavljanja i prekidanja prometnih tokova [3]. U području Inteligentnih Transportnih Sustava (ITS) postoji više rješenja za inteligentno odnosno na nižoj razini adaptivno upravljanje raskrižjima. Jedno od tih rješenja je promjena trajanja signalnih faza koristeći stvarnovremenske prometne podatke. Takav princip upravljanja za razliku od fiksnog upravljanja vrši promjenu trajanja zelenog ili crvenog svjetla ovisno o trenutnim prometnim parametrima. Veća kvaliteta ovakvog načina upravljanja postiže se stvarnovremenskom obradom odabranih ulaznih prometnih parametara.

Za tu svrhu koristi se niz pristupa kao što su razne optimizacijske metode, neizrazita logika, evolucijski algoritmi, neuronske mreže i ojačano učenje te njihove kombinacije. Neizrazita logika se kroz godine pokazala kao dobar alat za upravljanje složenim sustavima koji mogu poprimiti velik broj stanja. U ovom radu predložena su dva načina upravljanja trajanjem signalnih faza uporabom neizrazite logike. Predloženo rješenje je kreirano u simulacijskom okruženju sastavljenom od programskih alata VISSIM i MATLAB dok je za izračun emisija štetnih plinova korišten programski paket EnViVer.

Cilj ovog završnog rada je usporedba fiksnog i adaptivnog upravljanja signalnim planom semaforiziranog raskrižja mijenjanjem trajanje zelenog svjetla korištenjem neizrazite logike. Rad je podijeljen u sedam poglavlja. U drugom poglavlju opisan je princip rada semaforiziranih raskrižja. Treće poglavlje opisuje neizrazitu logiku i njenu primjenu u upravljanju semaforiziranim raskrižjima. U četvrtom poglavlju opisani su predloženi načini promjene trajanja vremena faze. Peto poglavlje daje pregled korištenog simulacijskog okruženja. U šestom poglavlju su prikazani korišteni prometni model, postavke sustava upravljanja te prikazani i analizirani rezultati simulacija. U posljednjem poglavlju dan je zaključak prema prethodnim poglavljima.

2 Problem upravljanja semaforiziranim raskrižjima

Svjetlosna signalizacija je važan instrument u području upravljanja prometom kojim se reguliraju način i količina prometa koji se slijeva u grad, uloga javnog gradskog prijevoza, teretni promet, promet u mirovanju ili zagađenje zraka uslijed prometa [4]. U urbanom okruženju uz vozila i prometnice glavni dio prometnog sustava predstavljaju semaforizirana raskrižja. Semaforizirano raskrižje opisuje se kao križanje prometnih tokova u istoj razini gdje je prolaz vozila upravljan vertikalnom svjetlosnom signalizacijom [5].

Upravljanje prometom sa semaforiziranim raskrižjima vrši se stvaranjem signalnog plana odnosno plana izmjena propuštanja prometnih tokova bez izazivanja konflikata među njima. Signalni plan se sastoji od najmanje dvije signalne faze. Signalna faza predstavlja vremenski period u kojem pojedini prometni tokovi imaju slobodan prolaz. Signalna faza može biti sačinjena od jedne ili više signalnih grupa odnosno grupiranih prometnih tokova. Vremenski period potreban da se izmjeni cijela sekvenca signalnih faza naziva se ciklus.

U slijedećim potpoglavljima opisane su razine upravljanja prometnom mrežom u gradu te strategije upravljanja semaforiziranim raskrižjima na razini pojedinačnog raskrižja.

2.1 Razine upravljanja prometom

U urbanoj sredini semaforizirana raskrižja predstavljaju izravan alat kojim se regulira protok vozila i usmjerava prometna potražnja. Grupiranjem što više raskrižja u jednu cjelinu te formiranjem prometnog centra koji koordinira njihovim radom raste razina upravljanja prometne mreže. Slijedeća podjela prikazuje četiri osnovne razine upravljanja semaforiziranim raskrižjima:

- Upravljanje izoliranim raskrižjem;
- Upravljanje raskrižjima na malom prostoru;
- Upravljanje arterijalnim koridorom;

- Upravljanje cijelom prometnom mrežom.

Upravljanje izoliranim raskrižjem je najniža razina upravljanja raskrižjem. Takav oblik upravljanja jest najjednostavniji jer se upravlja samo jednim raskrižjem te se u obzir ne uzimaju okolna raskrižja. Tvorba signalnih planova, to jest način vođenja prometa se zasniva na strategijama koje su navedene u nastavku rada. Ovakav način upravljanja može dovesti do negativnih posljedica kod susjednih raskrižja u slučaju nekvalitetnog planiranja te loše podešenog upravljačkog sustava.

Upravljanje raskrižjima na malom prostoru podrazumijeva koordinirano upravljanje s manjim brojem raskrižja. Koordinacija se provodi prema jednom odabranom raskrižju koje se gleda kao „glavno“ (engl. master) te se prema njemu vrši optimizacija signalnih planova ostalih raskrižja [6].

Upravljanje arterijalnim koridorom zasniva se koordinaciji signalnih planova niz arterijalnu ulicu. U odnosu na upravljanje na malom prostoru u ovakvom sustavu ne postoji glavno raskrižje već sva imaju istu težinu te se teži propuštanju što većeg broja vozila cijelim koridorom. Maksimalni protok vozila se postiže stvaranjem cestovnog "zelenog vala" kako bi vozila prošla bez zaustavljanja. U slučaju križanja više takvih ulica potrebno je koristiti jednake duljine ciklusa i vremenske odmake aktiviranja zelenog svijetla kako bi došlo do poklapanja rada sustava na raskrižju gdje se križaju te ulice.

Upravljanje cijelom prometnom mrežom je najviša razina upravljanja prometom na razini grada. Takav vid upravljanja podrazumijeva upravljanje svim ili većinom semaforiziranih raskrižja. Upravljanje cijelom prometnom mrežom se vrši iz centra za upravljanje prometom. Centar za upravljanje prometom predstavlja suvremeni ITS sustav kojemu su glavne zadaće pomoć korisnicima u izboru optimalne rute, stvarno-vremensko praćenje, analiza prikupljenih podataka, planiranje radnji vezanih za prikupljene podatke, mijenjanje signalnih planova u korist prioritetnih vozila, propuštanje određenih prometnih traka radi optimizacije toka prometa, vođenje službe za incidentne situacije u prometu, automatska klasifikacija i brojanje prometa te davanje meteoroloških podataka [7]. Ovakav način upravljanja omogućava implementaciju sustava adaptivnog upravljanja cijelom prometnom mrežom o čemu će još biti riječi u nastavku.

2.2 Strategije upravljanja semaforiziranim raskrižjima

Izmjenom trajanja signalnih faza, njihovog poretka ili odabirom potpuno drugog signalnog plana moguće je postići visoku razinu učinkovitosti djelovanja raskrižja. Navedene strategije kojima se opisuje rad semaforskih uređaja kreću od klasičnog fiksnog upravljanja koje ne reagira na trenutnu prometnu potražnju te završavaju s adaptivnim upravljanjem koje se zasniva na primjeni trenutnih podataka. Strategije upravljanja semaforiziranim raskrižjima su:

- Fiksno upravljanje;
- Prometno ovisno upravljanje;
- Adaptivno upravljanje.

2.2.1 Fiksno upravljanje

Fiksno upravljanje semaforiziranim raskrižjima odnosno vremenski ustaljeno upravljanje označava strategiju upravljanja raskrižjima po određenom planu izvođenja faza odnosno signalnih planova. Trajanje i građa signalnog plana se računa na osnovi podataka dobivenih brojanjem prometa. Ovakva vrsta upravljanja ne pruža mogućnost reagiranja na trenutne uvjete u prometu, no moguće je podesiti semaforski uređaj da podržava više signalnih planova. Na taj način je moguće prilagoditi odabir signalnog plana ovisno o dobu dana što je proračunato prema brojanju vozila i njihovoj kategorizaciji te uneseno u semaforski uređaj. Postoji i mogućnost sinkroniziranja semaforskih uređaja više raskrižja pomoću vremenskog pomaka početka posluživanja istog prometnog toka kako bi se postigao efekt kontinuiranog prolaska kroz više raskrižja odnosno zelenog vala na čemu se zasniva upravljanje arterijalnim koridorom.

Pozitivne strane fiksnog upravljanja naspram drugih strategija su relativno tehnički jednostavna i jeftina implementacija te semaforski uređaj koji ne mora biti povezan s drugim raskrižjima ili prometnim centrom. Trošak nakon implementacije se odnosi na povremeno održavanje te ponovno brojanje prometa radi osvježavanja signalnih planova. Zbog odsustva mogućnosti reagiranja na trenutnu prometnu situaciju ovakvo upravljanje nije primjereno raskrižjima na kojima postoji velika prometna potražnja s promjenjivim karakterom. Zbog odsustva mogućnosti reagiranja na trenutnu prometnu situaciju ovakvo

upravljanje se pokazuje loše kod prisustva velikih promjena u prometnoj potražnji u kratkom roku.

2.2.2 Prometno ovisno upravljanje

Za razliku od fiksnog upravljanja, prometno ovisno upravljanje pruža mogućnost reagiranja na prisustvo vozila na raskrižju. Takav sustav upravljanja se zasniva na detektiranju vozila te upravljačkom uređaju (računalu). Detekcija vozila se najčešće vrši pomoću senzora koji mogu dati podatak o tome da li je vozilo prošlo određenu mjesto i koliko se na njemu zadržalo [8]. Pomoću tih podataka i algoritama sadržanih u upravljačkom uređaju moguće je utjecati na trajanje i redoslijed faza. Pripadni upravljački algoritmi sadrže predodređene vrijednosti minimalnoga i maksimalnog trajanja faze te iznosa za koliko je dozvoljeno produljiti fazu. Primjer jednog takvog jednostavnog sustava upravljanja bio bi: „Ukoliko na privozu ima više od X vozila u repu čekanja, trajanje zelenog svijetla se produljuje za Y sekundi“ [6]. Također, u slučaju odsustva vozila na određenom privozu moguće je preskočiti fazu namijenjenu za taj privoz kako bi se propustio neki drugi prometni tok. Moguće je i implementirati sustav koji s dva detektora može izmjeriti brzinu nadolazećeg vozila te ako je brzina viša od dopuštene promijeniti signalni pojam u crveno kako bi se vozač zaustavio.

Ovakav sustav upravljanja je blizak adaptivnom upravljanju, no zbog ograničenosti izvora podataka i „inteligencije“ upravljačke logike takav princip rada ne može u potpunosti odgovoriti trenutnim potrebama povećane prometne potražnje. Što se posebno očituje kod značajnih promjena prometne potražnje tijekom dana.

2.2.3 Adaptivno upravljanje

Adaptivno upravljanje prometom na semaforiziranim raskrižjima označava upravljanje koje se prilagođava trenutnom stanju na prometnicama. Primarna razlika između adaptivnog i prometno ovisnog upravljanja je u dostupnim informacijama dobivenim s prometnice. Prometno ovisno upravljanje se zasniva samo na signalu senzora o prisutnosti vozila, dok se kod adaptivnog upravljanja semaforiziranim raskrižjem upravlja primjenom složenijih prometnih parametara kao što su: tok, gustoća, zauzeće, duljina repa čekanja i dr. Neki od senzora koji se mogu koristiti za adaptivno upravljanje su: induktivne petlje, radar, kamere, Bluetooth senzori, senzori vremenskih uvjeta, itd. Pomoću tih senzora

moгуće je dobiti dobar uvid u stanje na prometnicama kroz prometne parametre kao što su: volumen prometnog toka, rata toka, brzina vozila, tip vozila, itd.

U odnosu na koordinirani fiksni režim rada semafora (s predodređenim redoslijedom uključivanja signalnih pojmova i trajanjem faza u ciklusu), adaptivni sustav je složeniji, ali bitno učinkovitiji jer smanjuje ukupne vremenske gubitke i ostale pokazatelje kvalitete [9]. Osim nabrojanih poboljšanja, razvijanje i implementacija ovakvih sustava također pridonosi digitalizaciji semaforiziranih raskrižja čime se olakšava održavanje infrastrukture te nadzor nad prometnom mrežom.

Smanjenje vremena putovanja i duljine repova čekanja te povećanje sigurnosti i propusne moći postiže se tehnikama promjene rasporeda faza, promjene trajanja faza (koje su поближе objašnjene dalje u radu), dodjelom prioriteta vozilima javnog gradskog prijevoza ili vozilima žurne službe, informiranjem putnika odnosno vozača, upravljanjem priljevnim tokovima, upravljanjem ograničenjem brzina te drugim ITS rješenjima.

Razvoj komercijalnih adaptivnih sustava upravljanja prometom (engl. ATCS - Adaptive Traffic Control Systems) započeo je 1970-ih u Australiji razvojem SCATS-a (engl. Sydney Coordinated Adaptive Traffic System). Grad Toronto u Kanadi je implementirao sustav SCOOT 1998. godine te od onda ima izračunatu godišnji dobitak u iznosu od 984.186 \$ [10]. Ubrzo nakon uspjeha tog sustava počeli su se pojavljivati novi sustavi od kojih je svaki pružao drugačiji pristup problematici. Neki od najpoznatijih komercijalnih adaptivnih sustava upravljanja prometom su:

- SCOOT - Split Cycle and Offset Optimisation Technique;
- SCATS - Sydney Coordinated Adaptive Traffic System;
- UTOPIA - Urban Traffic Optimisation by Integrated Automation;
- RHODES - Real-time Hierarchical Optimized Distributed Effective System.

2.3 Metode za promjenu trajanja signalnih faza


Ključna zadaća adaptivnih sustava upravljanja prometom je promjena trajanja signalnih faza kako bi se što bolje odgovorilo na trenutne prometne uvjete. Jednako kao što se može odlučivati o trajanju faze zelenog svijetla tako se može mijenjati i trajanje faze crvenog svijetla. Skraćivanje trajanja crvene faze pronalazi svoje mjesto kod dodjeljivanja

prioriteta vozilima javnog gradskog prijevoza ili žurnih službi. Fokus ovog završnog rada je na promjeni trajanja faze zelenog svjetla. Postoje dva načina na koji se može utjecati na trajanje faze:

- Metodom odlučivanja na početku faze (MOP) o trajanju faze;
- Metodom kontinuiranog odlučivanja (MKO) o trajanju faze.

Kod obje metode potrebno je odrediti minimalno i maksimalno trajanje faze, odnosno u nekim slučajevima minimalno trajanje ne mora biti određeno te je time moguće propustiti fazu ako nije zadovoljena dovoljna potražnja. Maksimalno produljenje nije standardizirano jer ovisi o pojedinačnom raskrižju. Različiti autori propisuju različite vrijednosti tako da su u [11] preporučene vrijednosti do 50 posto trajanja faze dok se u [12] preporučuje držanje u vremenskom okviru od 10 do 20 [s] produžavanja od početnog vremena trajanja.


Donošenje odluke o trajanju faze na njenom početku zasniva se na količini akumuliranih vozila u repu čekanja za trajanja prethodne signalne faze te po potrebi količina priljevnih i odljevnih tokova te signalne grupe. U takvom načinu rada definirano je minimalno i maksimalno trajanje faze odnosno trajanje zelenog svjetla. Potrebno je odlučiti koliko će dugo trajati zeleno svjetlo nakon isteka njenog minimalnog trajanja. Ako se odluči da faza ne treba biti produžena prelazi se na sljedeću fazu, a ako je faza produljena onda se tek nakon isteka vremena produljenja prelazi u sljedeću fazu. Rad ove metode je prikazan na slici 1.



Slika 1: Prikaz produljivanja faze - MOP

Na slici 2 je prikazan princip rada metode kontinuiranog produljivanja faze. Ta metoda promjene trajanja faze zasniva se na periodičkom produljivanju faze ako za time postoji potreba. Nakon isteka minimalnog trajanja faze ispituje se da li ima potrebe za produljivanjem faze. U slučaju zagušenja, faza se produljuje za neki manji iznos vremena

te se nakon što to vrijeme istekne ponovno odlučuje o novom produljivanju te se taj postupak može ponavljati sve dok se trajanje faze ne izjednači s maksimalnim trajanjem faze. Vrijednost za koliko se produljuje faza je proizvoljna te može biti stalna ili promjenjiva kao u SCOOT-u gdje može iznositi između 1 i 4 [s] ovisno o potrebi [13].



Slika 2: Prikaz produljivanja faze - MKO

Za donošenje odluke da li produljiti fazu te za koliko, moguće je koristiti algoritme koji se zasnivaju na predodređenim vrijednostima (kao što se koriste kod prometno ovisnog upravljanja), sustave neizrazite logike, evolucijske algoritme te druge sustave u sferi umjetne inteligencije. U ovom završnom radu su istražene obje navedene metode promjene trajanja signalnih faza korištenjem neizrazite logike za donošenje odluka.

3 Neizrazita logika i njena primjena u upravljanju semaforiziranim raskrižjima

Od 1960-ih godina neizrazita logika postaje važan dio inženjerstva te pronalazi sve veću primjenu u konkretnim rješenjima, a ne samo kao matematički koncept. Zbog mogućnosti podešavanja sustava neizrazite logike ljudski razumljivim parametrima i načinima, neizrazita logika se pokazala kao dobra za upravljanje sustavima čije nepoznanice mogu poprimiti niz značajno različitih vrijednosti. Kao takva, neizrazita logika je pronašla svoje mjesto i u tehnologiji prometa. Razvijena su razna rješenja kao što su neizraziti sustavi za upravljanje ubrzanjem vozila, za optimizaciju transportnih ruta, za davanje prioriteta žurnim službama te za upravljanje semaforiziranim raskrižjima. Kod upravljanja semaforiziranim raskrižjima pomoću neizrazite logike koriste se tehnike promjene trajanja faze ili promjene rasporeda faze (također se mogu koristiti i u kombinaciji).

3.1 Neizrazita logika

Ideja logike u kojoj nepoznanica može poprimiti beskonačno mnogo vrijednosti javlja se 1920-ih godina. Takva logika za razliku od klasične Bool-ove logike dopušta nepoznanicama da poprime bilo koju vrijednost. Iz te ideje je 1965. godine Loft A. Zadeh razvio svoju teoriju neizrazitih (engl. fuzzy) skupova koja je prerasla u ono što danas poznajemo kao neizrazitu logiku [14]. Stanja klasične logike, odnosno istina ili laž smatraju se specijalnim slučajem neizrazite logike jer pokrivaju samo dva rubna ishoda od njih beskonačno mnogo između. Iz tog razloga se neizrazita logika naziva generalizacijom klasične logike. Važnost neizrazite logike se javlja u lakom prijenosu informacija iz ljudski razumljive, govorne, forme u brojke. Dopusćen broj stanja neizrazite nepoznanice je ograničen jedino količinom potrebnih stanja. Iz tog razloga je moguće relativno jednostavno opisati sustave višeg reda neizrazitom logikom. Zato je pomoću neizrazite logike sada moguće jednostavno definirati i obraditi tvrdnje poput „vrata su vrlo malo otvorena“ ili „temperatura je srednje visoka“. Neizrazita logika je pronašla svoje mjesto u inženjerstvu kroz neizrazite regulatore procesa.

U Ujedinjenom Kraljevstvu je profesor Ebrahim Mamdani dizajnirao prvi neizraziti regulator za parni stroj koji se kasnije koristio za upravljanje proizvodnim procesom cementare u Danskoj te označava prvi veliki uspjeh neizrazite logike u komercijalnom svijetu [15]. U Japanu je također ideja neizrazite logike bila vrlo popularna te je firma Hitachi razvila neizraziti sustav za kočenje i ubrzanje vlakova u japanskom gradu Sendai. Koristi neizrazite logike su vidljive i u svakodnevnim tehnološkim rješenjima kao što su ventilacijski sustavi, sustavi grijanja, u ekonomiji i u obradi video zapisa.

Neizraziti skup je skup objekata opisan promjenom iznosa pripadnosti. Takav skup je okarakteriziran funkcijom pripadnosti koja svakom objektu skupa dodjeljuje ocjenu pripadanja koja se kreće od 0 do 1 [14]. Funkcija pripadnosti može biti bilo koja matematička funkcija. Najčešće se koriste: trokutna, trapezna, eksponencijalna i normalna krivulja. Na slici 3 su prikazane funkcije pripadnosti za temperaturu. Klasična logika je u ovom slučaju ograničena na tri vrijednosti: niska, srednja i visoka temperatura, dok neizraziti skupovi mogu okarakterizirati neku temperaturu kao više nižu nego srednju.



Slika 3: Prikaz funkcija pripadnosti temperature

Neizraziti skupovi su zanimljiva matematička formulacija, no same po sebi ih se ne može koristiti za upravljanjem nekim procesom bez dodatnog mehanizma za obradu izmjerenih vrijednosti u sustavu. Taj mehanizam su neizrazita pravila. Neizrazitim pravilima teži se pokriti što veći broj mogućih kombinacija ulaznih nepoznanica kako bi odgovor sustava bio kvalitetan. To su pravila tipa Ako-Onda koja funkcioniraju kao i hipotetični sudovi u klasičnoj logici. Pravila se sastoje od najmanje dvije premise (ulaznih varijabli i njihovih vrijednosti) te daju zaključak (izlaznu varijablu i njenu vrijednost). Primjer takvih pravila se nalazi u tablici 1. Za obradu varijabli u pravilima se koriste posebne operacije zvane Zadeh-ove logičke operacije.

Tablica 1: PRIMJER NEIZRAZITIH PRAVILA U UPRAVLJANJU SUSTAVOM VENTILACIJE

	<i>Temperatura</i>		<i>Vlaga</i>		<i>Tlak</i>		<i>Jačina</i>
<i>ako</i>	<i>NISKA</i>	<i>i</i>	<i>NISKA</i>	<i>i</i>	<i>NIZAK</i>	<i>onda</i>	<i>SLABO</i>
<i>ako</i>	<i>NISKA</i>	<i>i</i>	<i>SREDNJA</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>SREDNJE</i>
<i>ako</i>	<i>SREDNJA</i>	<i>i</i>	<i>SREDNJA</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>JAKO</i>
<i>ako</i>	<i>VISOKA</i>	<i>i</i>	<i>VISOKA</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>VRLO JAKO</i>

Sustav neizrazite logike zasnovan je na tri procesa koji se izvode po danom redu:

1. Fuzzifikacija – pretvaranje brojčanih vrijednosti ulaznih varijabli u neizrazite vrijednosti;
2. Evaluacija pravila – primjenjivanje pravila o ponašanju sustava na funkcije pripadnosti;
3. Defuzzifikacija – pretvaranje neizrazite vrijednosti izlazne varijable u brojčanu vrijednost.

Neizrazita logika omogućuje lakše modeliranje složenih sustava te ne zahtjeva opisivanje svakog mogućeg ishoda, već kroz svoja pravila i funkcije pripadnosti s manjim brojem „površina“ opisuje ponašanje sustava. Korištenje neizrazite logike u rješavanju inženjerskih problema je postojano od njenog nastanka te daje još i bolje rezultate u kombinaciji s evolucijskim algoritmima, neuronskim mrežama te drugim algoritmima.

3.2 Pregled postojećih rješenja

Prvo istraživanje o korištenju neizrazite logike u upravljanju semaforiziranim raskrižjima proveli su Pappis i Mamdani [16] 1977. godine. Primijenivši sustav neizrazitog odlučivanja o promjeni trajanja zelenog svjetla na modelu izoliranog raskrižja dvije jednosmjerne ulice, dobili su bolje rezultate u odnosu na prometno ovisno upravljanje raskrižjem te time postavili temelj za mnoge znanstvene radove uključujući i ovaj završni rad.

Trabia i ostali [17] su aproksimirali priljevne tokove i repove čekanja koristeći induktivne petlje te razvili neizraziti sustav koji svaki određeni vremenski interval odlučuje treba li prekinuti ili nastaviti tekuću fazu zelenog svjetla.

Osim upravljanje trajanjem faze zelenog svjetla, Murat i Gedizlooglu [18] su razvili sustav promjene rasporeda faza unutar signalnog plana. Na izoliranom raskrižju u slučaju

s tri ili četiri faze postigli su bolje rezultate u odnosu na prometno ovisno upravljanje i modele dane u programskom paketu SIDRA za analizu raskrižja. Pogotovo u scenariju visoke promjenjivosti prometne potražnje.

Kako bi se pokrio veći broj prometnih scenarija, Nair i Cai [19] su u svoj model izoliranog raskrižja dodali mogućnost pojave simulirane nesreće ili rada na cesti. Neizraziti sustav promjene trajanja faze zelenog svjetla koji su konstruirali se uspješno mogao prilagoditi i tim događajima.

Chiou i Lan [20] su izradili genetski algoritam za podešavanje funkcija pripadnosti i neizrazitih pravila sustava promjene trajanja faze zelenog svjetla koristeći vrijeme čekanja vozila kao kvalitativnu varijablu. Dobiveni sustav postiže gotovo jednake rezultate kao optimalni signalni plan za pretpostavljeno raskrižje. Kod promjena u količini prometne potražnje u rasponu od 10 do 50 %, sustav je ostvario bolje rezultate od fiksnog upravljanja s više signalnih planova koji su se aktivirali ovisno o količini prometne potražnje.

Qiao i ostali [21] su također izradili genetski algoritam za optimiranje funkcija pripadnosti i neizrazitih pravila, no osim promjene trajanja zelenog svjetla kao u [20] također su i razvili segment za promjenu rasporeda faza. Simulacijski rezultati su se pokazali bolji nego kod prometno ovisnog upravljanja.

Wei i Zhang [22] su uz korištenje neizrazite logike za donošenje odluke treba li produljiti tekuću fazu ili ne koristili i kombinaciju neuronskih mreža s neizrazitom logikom za predviđanje prometnih parametara koji se koriste za odlučivanje o produljenju. Simulacijski rezultati su pokazali da sustav smanjuje vrijeme čekanja vozila i postotak zaustavljanja vozila.

Za razliku od dosad navedenih radova, Niittymäki i Kikuchi su u [23] predstavili neizraziti sustav za upravljanje signala koji propušta pješake preko prijelaze. Cilj sustava je pronaći kompromis između minimiziranja čekanja pješaka i minimiziranja čekanja i broja stajanja vozila. Sustav se pokazao kao barem jednako dobar i bolji od sustava prometno ovisnog upravljanja.

Kako bi se bolje razumjelo ponašanje vozača u situacijama gdje se donosi odabir o tome hoće li smanjiti ili povećati brzinu kada se pojavi signal žutog svjetla na raskrižju, Hurwitz i ostali [24] su konstruirali neizraziti sustav. Istraživanje je rezultiralo povećanjem sigurnosti na raskrižjima kroz bolje shvaćanje određivanja signalnih planova te pozicija detektora vozila.

4 Neizraziti sustav za produljenje vremena trajanja faze


Kako bi se odredila optimalna promjena trajanja faze potrebno je uzeti u obzir trenutno prometno stanje na upravljanom semaforiziranom raskrižju. Sustav neizrazite logike služi kao funkcija koja kao svoj ulaz preuzima niz prometnih parametara, a kao svoj izlaz daje jednu ocjenu o stanju u prometu. Pomoću dobivene ocijene hitnosti, moguće je izvesti promjenu vremena trajanja faze koja odgovara trenutnim potrebama.

Kako bi se donijela odluka o tome za koliko promijeniti trajanje faze, odnosno da li uopće ima potrebe za time potrebno je odrediti stanje na svim prometnim trakama koje pripadaju signalnim grupama promatrane faze. Zbog neravnomjernosti u količini prometnog opterećenja, prometne trake se dijele na one koje pripadaju glavnom te na one koje pripadaju sporednom prometnom toku. Iz toga proizlazi potreba za konstruiranjem dva neizrazita sustava odlučivanja za pojedini tip prometnog traka. Sustav za trake glavnog toka konfigurira se tako da u odnosu na sporedni tok lakše postiže višu ocjenu hitnosti kako bi se dala prednost pravcima glavnog prometnog toka. Ta odluka se opravdava razlikom u prometnom volumenu odnosno podizanju propusnosti glavnog toka s manjim padom propusnosti sporednog toka.

Ulazne varijable oba sustava su jednake te su one: rep čekanja, priljevni i odljevni tok. Rep čekanja je parametar koji govori od trenutnoj količini vozila u traci, na njega je sustav najosjetljiviji. Priljevni i odljevni tok su parametri koji govore o količini vozila koji su prošli nekim presjekom u jednom satu. Priljevni tok se mjeri na ulazu u privoz raskrižja odnosno, u smjeru prema raskrižju te daje sustavu sliku o promjenama u pristizanju vozila. Odljevni tok se mjeri na izlazu iz raskrižja te daje informaciju o radu sustava koji upravlja raskrižjem odnosno o količini vozila koja prođe kroz raskrižje u jednom satu.

Kako bi se izmjerene ulazne vrijednosti mogle obrađivati unutar neizrazitog sustava, potrebno je napraviti odgovarajuće funkcije pripadnosti za svaku ulaznu varijablu odnosno radi provođenja procesa fuzzifikacije. Na slici 4 prikazane su funkcije pripadnosti varijable rep čekanja za trake glavnog prometnog toka. Na horizontalnoj osi je prikazan postotak

popunjenosti repa čekanja, a na vertikalnoj osi je prikazana pripadnost koju funkcije zahvaćaju.



Slika 4: Prikaz funkcija pripadnosti repa čekanja

Osim funkcija pripadnosti također je potrebno izraditi skup neizrazitih pravila koja će davati izlaznu vrijednost sustava (hitnost) ovisno o ulazima u sustav. Neizrazita pravila moraju biti napravljena tako da pokriju što veći broj mogućih prometnih scenarija, odnosno da izračunaju dobru vrijednost hitnosti te za smanjene i povećane prometne volumene. Konkretnije, za situacije smanjene prometne potražnje poželjno je imati kraće vrijeme trajanja pojedinih faza kako bi se ravnomjerno i često praznili svi privozi. Suprotno tome, za situacije povećane prometne potražnje teži se dopuštanju dužeg propuštanja vozila privoza koji se nalazi pod većim prometnim opterećenjem.


Ručno stvaranje tih pravila je dugotrajan proces koji započinje sa zdravo razumskim i inženjerskim pretpostavkama te završava procesom pokušaja i pogreške. Radi olakšavanja toga procesa se danas primjenjuju evolucijski algoritmi koji optimiraju ručno definirana pravila. U tablici 2 prikazan je dio stvorenih pravila neizrazitog sustava za trake glavnog prometnog toka.

Kao što je spomenuto izlazna varijabla sustava naziva se hitnost trake te je to vrijednost u rasponu od -1 do 1 . Dobiva se defuzzifikacijom neizrazite vrijednosti dobivene obradom neizrazitim pravilima ulaznih varijabli. Hitnost vrijednosti -1 govori da promatrana prometna traka nije nimalo zagušena i ne predviđa se njeno skorašnje zagušenje, vrijednost 0 predstavlja srednje zagušenje trake dok vrijednost 1 označava potpuno zagušenje trake te slab odziv sustava na prometno opterećenje. Posebnost neizrazitog sustava odlučivanja se nalazi u rezultatnim vrijednostima između -1 i 1 koje pokrivaju sve situacije između

Tablica 2: IZVADAK NEIZRAZITIH PRAVILA 17.-32.

	Rep čekanja		<i>Priljevni tok</i>		<i>Odljevni tok</i>		<i>Hitnost</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>NIZAK</i>	<i>i</i>	<i>NIZAK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>NIZAK</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>NIZAK</i>	<i>i</i>	<i>VISOK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>NIZAK</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>SREDNJI</i>	<i>i</i>	<i>NIZAK</i>	<i>onda</i>	<i>SREDNJA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>SREDNJI</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>SREDNJA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>SREDNJI</i>	<i>i</i>	<i>VISOK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>SREDNJI</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>VISOK</i>	<i>i</i>	<i>NIZAK</i>	<i>onda</i>	<i>VISOKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>VISOK</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>SREDNJA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>VISOK</i>	<i>i</i>	<i>VISOK</i>	<i>onda</i>	<i>SREDNJA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>VISOK</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>onda</i>	<i>NISKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>i</i>	<i>NIZAK</i>	<i>onda</i>	<i>VISOKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>i</i>	<i>SREDNJI</i>	<i>onda</i>	<i>VISOKA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>i</i>	<i>VISOK</i>	<i>onda</i>	<i>SREDNJA</i>
<i>ako</i>	<i>SREDNJI</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>i</i>	<i>JAKO VISOK</i>	<i>onda</i>	<i>SREDNJA</i>

praznog i potpuno zagušenog raskrižja. Na slici 5 prikazane su funkcije pripadnosti varijable hitnost. Hitnost može poprimiti pet neizrazitih vrijednosti kako bi se pokrio što širi spektar zagušenosti prometne trake. Slijedeće je objašnjeno korištenje hitnosti za odlučivanje o trajanju faze koristeći metodu odlučivanja na početku faze [25] te metodu kontinuiranog odlučivanja.



Slika 5: Prikaz funkcija pripadnosti hitnosti

4.1 Metoda odlučivanja na početku faze

Za računanje vremena trajanja faze korištenjem metoda odlučivanja na početku faze potrebno je izračunati hitnost svih prometnih traka sadržanih unutar faze na njenom početku. Kako bi se dobila ukupna hitnost, potrebno je zbrojiti te hitnosti te izračunati njihovu aritmetičku sredinu kao u izrazu 1.

$$H_{faze} = \frac{\sum_{i=1}^n H_{traka_i}}{n} \quad (1)$$

Gdje je:

H_{faze} - ukupna hitnost svih traka;

H_{traka_i} - hitnost trake;

n - broj traka.

Zatim je potrebno izračunati za koliko se najviše može promijeniti trajanje faze. Taj broj se dobiva umnoškom zadanog trajanja faze s koeficijentom promjene trajanja faze (KPT) koji govori za koliko je najviše moguće promijeniti trajanje faze. Time se dobiva ΔT_{max} , vidi izraz 2.

$$\Delta T_{max} = T_{faze} \cdot KPT \quad (2)$$

Gdje je:

ΔT_{max} - iznos za koji se najviše može promijeniti trajanje faze;

T_{faze} - zadano trajanje faze;

KPT - koeficijent trajanja faze.

Kako bi se dobio iznos za koji se mijenja trajanje faze potrebno je pomnožiti najveći mogući iznos promjene s ukupnom hitnošću kao u izrazu 3. Ako je taj broj ΔT pozitivan onda će se za njegov iznos produljiti faza, a ako je negativan onda će se za toliko skratiti u odnosu na zadanu vrijednost:

$$\Delta T = H_{faze} \cdot \Delta T_{max}, \quad (3)$$

gdje je:

ΔT - iznos za koji se mijenja trajanje faze;

H_{faze} - ukupna hitnost svih traka;

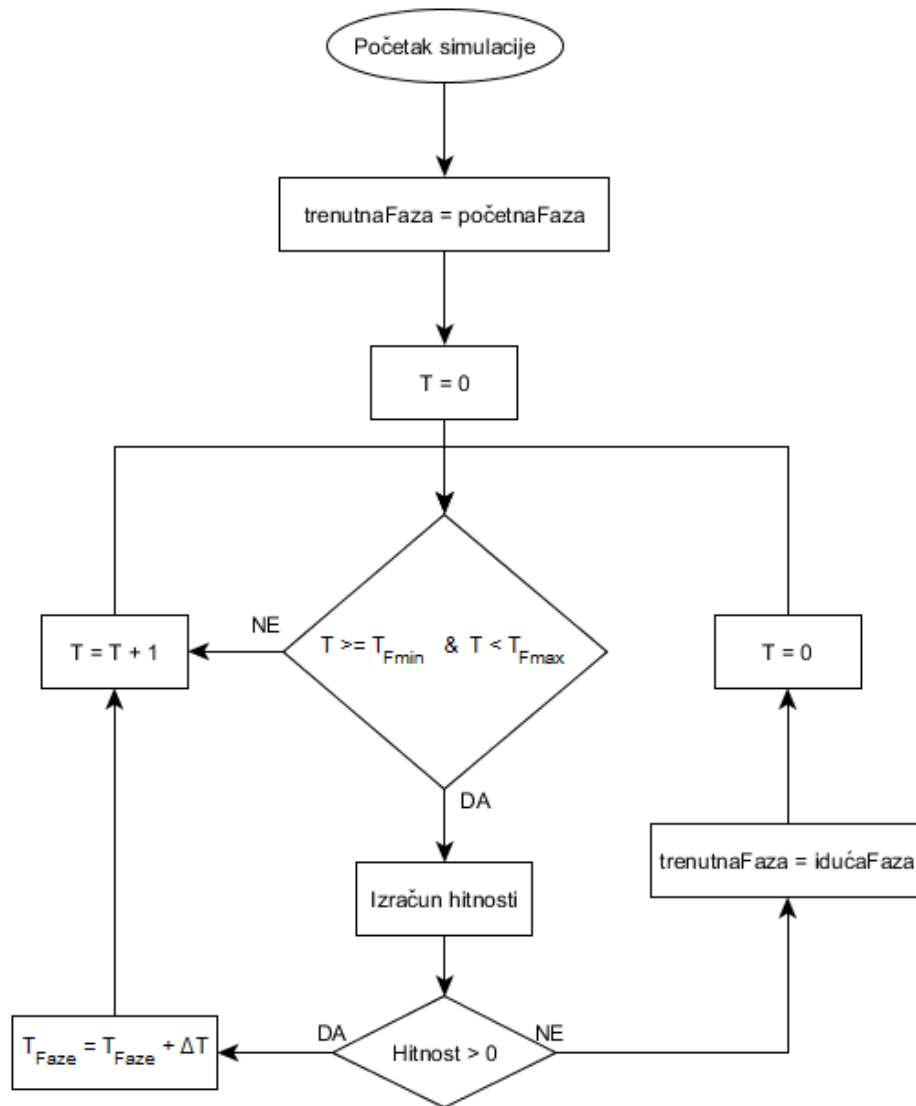
ΔT_{max} - iznos za koji se najviše može promijeniti trajanje faze.

Na taj način izračunata promjena trajanja faze se pribraja vrijednosti trajanja zelenog svjetla za odabranu fazu i time završava ova metoda.

4.2 Metoda kontinuiranog odlučivanja

Za razliku od prethodno opisane metode, kod metode kontinuiranog odlučivanja (MKO) potrebno je i pobliže popratiti trajanje i vrijeme uključivanja zelenog svjetla signalnih grupa unutar faze. U slučaju da je faza sačinjena od više signalnih grupa potrebno je odrediti kojoj signalnoj grupi prvoj završava zeleno svjetlo te na njenom kraju započeti s eventualnim produljivanjem faze. Na slici 6 je prikazan dijagram toka izvođenja simulacijske petlje koristeći MKO.

Nakon što je dostignuto minimalno trajanje zelenog svjetla signalne grupe (T_{Fmin}), koja se prva završila, računa se hitnost svih prometnih traka u fazi. Za razliku od prethodne metode ne računa se ukupna hitnost već je pozitivna vrijednost hitnosti barem jedne trake dovoljna da se trajanje faze produži za neki iznos ΔT . Nakon što je istekne produljenje

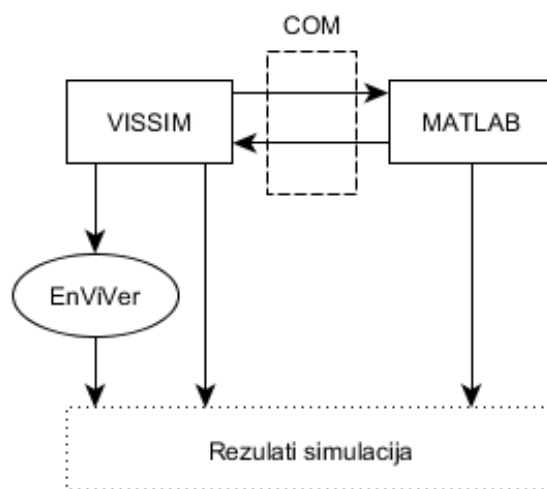


Slika 6: Dijagram toka izvođenja simulacije korištenjem MKO

ΔT i trajanje faze nije dostiglo svoju maksimalnu vrijednost (T_{Fmax}) ponovno se računa ima li potrebe za produljivanjem, a ako nema, faza se nastavlja sve dok ne dođe do kraja iduće signalne grupe kada se proces ponavlja. U slučaju da se faza sastoji od samo jedne signalne grupe, algoritam se izvršava na njenom kraju te faza završava ako nije bilo potrebe za produljivanjem nakon isteka minimalnog trajanja faze.

5 Simulacijsko okruženje PTV VISSIM/MATLAB

Algoritmi predloženih metoda promjene trajanja zelenog svjetla i odgovarajući neizraziti sustavi odlučivanja napravljeni su u programskom paketu MATLAB. Simuliranje prometne mreže izvršeno je u programskom paketu VISSIM. Veza između ta dva paketa potrebna za računanje trajanja zelenog svjetla te namještanje signalnih pojmova je ostvarena korištenjem COM sučelja. Također je napravljena i evaluacija emisije štetnih ispušnih plinova koristeći programski paket EnViVer. Na slici 7 je prikazan shematski prikaz primijenjenog okruženja. U ovom poglavlju su navedeni programski paketi поближе objašnjeni.



Slika 7: Shematski prikaz simulacijskog okruženja


5.1 MATLAB

MATLAB (engl. MATrix LABoratory) je programsko okruženje prvobitno stvoreno za rješavanje matematičkih problema linearne algebre. S vremenom je MATLAB postao okolina za razvijanje i implementaciju algoritama, analizu i vizualizaciju podataka interakciju s drugim programima i programskim jezicima [26]. U usporedbi s drugim programskim jezicima, MATLAB omogućava lakše rješavanje matematičkih problema zato jer mu je osnovni tip podatka matrica s kompleksnim brojevima. Sintaksa MATLAB koda omogućava lakše zapisivanje matematičkih formulacija te u kombinaciji s matricom kao tipom podatka omogućava elegantnije računanje za razliku od programskih jezika zasnovanih na manipulaciji skalarnim vrijednostima kao što su C++ ili Fortran. Iz razloga što MATLAB služi kao interpreter kôda, izvođenje programa je brzo i ugrađeni alat za uređivanje i ispravljanje pogrešaka (engl. debugging tool) pruža visoku razinu učinkovitosti programiranja. Uz osnovni dio programskog okruženja također postoji i niz programskih alata (engl. toolboxes) koji funkcioniraju kao nadogradnje. Zbog otvorenosti MATLAB-a svi korisnici mogu sami kreirati svoje alate te postoji velika i aktivna zajednica ljudi koji doprinose svojim alatima [27]. Neke od nadogradnji su:

- Fuzzy Logic Toolbox – nadogradnja za razvijanje sustava neizrazite logike;
- Statistics and Machine Learning Toolbox – nadogradnja za opisivanje, analiziranje i modeliranje podataka;
- Neural Network Toolbox – nadogradnja koja pruža algoritme, modele i aplikacije za stvaranje neuronskih mreža;
- Simulink Control Design – nadogradnja za dizajniranje i analiziranje sustava upravljanja;
- Signal Processing Toolbox – nadogradnja koja pruža funkcije i aplikacije za analiziranje, pretprocesiranje i ekstrakciju svojstava uzorkovanih signala;
- Image Processing Toolbox – nadogradnja pruža set algoritama i aplikacija za analizu slika i razvijanje algoritama.

5.2 VISSIM

Simulacije cestovnog prometa u ovom radu se odvijaju korištenjem mikroskopskog simulacijskog programa VISSIM tvrtke PTV. Postoje mikroskopske, mezoskopske i makroskopske simulacije u prometu. U mikroskopskim simulacijama definirani su elementi prometne mreže do razine samog vozila te njegovog ponašanja. Putanje i ponašanje vozača zasnovano je na okolnim vozilima. Mikroskopske simulacije služe za analizu manjih prometnih mreža dok makroskopske simulacije, koje koriste pravila mehanike fluida za modeliranje flote vozila, mogu simulirati velike prometne mreže. Mezoskopske simulacije su hibrid mikroskopskih i makroskopskih simulacija. VISSIM je simulacijski program zasnovan na Wiedemann psiho-fizičkom modelu koji opisuje ponašanje vozača u prometu. Neki od prometnih aspekata koje je moguće simulirati u VISSIM-u su: semaforizirana i nesemaforizirana raskrižja, kružni tokovi, javni prijevoz (tramvajski, autobusni i željeznički), pješake, autoceste, naplatne postaje itd. Na slici 8 je prikazano grafičko sučelje programskog paketa VISSIM.



Slika 8: Prikaz grafičkog sučelja mikroskopskog simulatora PTV VISSIM

Osim korištenja već ugrađenih mehanizama za simuliranje složenijih prometnih događaja kao što su javni prijevoz, upravljanje semaforiziranim raskrižjima i naplatne postaje, VISSIM nudi mogućnost interakcije s drugim aplikacijama radi razvijanja složenih sustava upravljanja prometom. Vezom VISSIM-a i drugih aplikacija moguće je napraviti sustave za

upravljanje promjenjivim ograničenjem brzine [28], sustave za davanje prioriteta [29], sustave promjene redoslijeda faza na semaforiziranim raskrižjima te sustav poput predloženog u ovom završnom radu.

5.3 Povezivanje MATLAB-a i VISSIM-a

Komunikacija između MATLAB-a i VISSIM-a ostvarena je koristeći COM (engl. Component Object Model) sučelje. COM definira normu koji je primijenjen na mnogo operativnih sustava i različitih sklopovskih okolina [30]. Definiranje COM sučelja omogućava razmjenu objekata između više okolina neovisno o načinu na koji su stvoreni unutar početne okoline. U ovom radu se ostvaruje veza s MATLAB-om kao klijentskim programom i VISSIM-om kao poslužiteljem. Na početku izvođenja MATLAB koda se ostvaruje veza s prometnim modelom u VISSIM-u i inicijalizira početno stanje te se pokreće simulacija. Kroz simulaciju se vrši konstanta razmjena podataka između dva programa te se zaustavlja VISSIM-ovim isporučivanjem podataka za obradu podataka simulacije.

5.4 EnViVer


Za analizu količine emisija štetnih plinova korišten je programski dodatak EnViver. Taj program na temelju podataka o izvršenoj simulaciji iz VISSIM-a može izračunati vrijednosti emitiranih štetnih plinova po odabranom modelu. Za potrebe računanja vrijednosti emisija u EnViVer-u izmjerene su emisije štetnih plinova 3.000 vozila [31]. U ovom završnom radu su analizirane emisije CO_2 , NO_X i PM_{10} . EnViVer nudi mogućnost modeliranja performansi voznog parka u vidu distribucije starosti vozila, tipa vozila, prosječnoj emisiji CO_2 itd. [28]. U završnom ovom radu je korišten model emisija dostupan u programskom paketu, model Danskog voznog parka iz 2018. godine. Time je omogućena relativna usporedba utjecaja pojedinih načina upravljanja semaforiziranim raskrižjem na ekološke parametre. Za apsolutnu usporedbu potrebno je iskoristiti podatke o voznom parku i sastavu vozila za analizirano raskrižje te pripadnu državu.

6 Simulacijski rezultati

U ovom poglavlju prikazani su rezultati usporedbe dvije predložene metode promjene trajanja faze. Izvođenje tih metoda je izvršeno na dvofaznom izoliranom raskrižju. Rezultati prikazuju prometne parametre navedenih metoda u usporedbi s fiksnim upravljanjem raskrižjem. Osim prometnih parametara, prikazana je i duljina trajanja ciklusa što vizualno prikazuje odgovaranje sustava na trenutne potrebe upravljanog raskrižja.


6.1 Model i postavke

Model izoliranog raskrižja s dvije faze i četiri privoza prikazan na slici 10 napravljen je u VISSIM-u. Ovo je model raskrižja Ulica kralja Zvonimira - Harambašićeva ulica u istočnom dijelu grada Zagreba. Signalni plan ovog raskrižja se sastoji od dvije faze te ciklus traje 90 [s]. Prvu fazu čine signalne grupe V_2 i V_4 odnosno vozila sjevernog i južnog privoza. Trajanje zelenog svjetla signalne grupe V_2 iznosi 30 [s], a signalne grupe V_4 35 [s] kao što je prikazano na slici 9. Drugu fazu čine signalne grupe V_1 (istočni privoz) i V_3 (zapadni privoz) te trajanje zelenog svjetla za obje iznosi 40 [s].



Slika 9: Signalni plan promatranog raskrižja

Sa strelicama različitih boja na slici 10 modela su naznačeni detektori koji se dijele na detektore: repa čekanja - zelene strelice, priljeva vozila - plave strelice i odljeva vozila - crvene strelice. Za detektore repa čekanja glavnog prometnog toka uzeta je udaljenost 100 [m] od stop crte, a za sporedni tok, 40 [m].



Slika 10: Prikaz modela raskrižja i razmještaj detektora

Za određivanje minimalnog i maksimalnog promijenjenog trajanja faze korištena je vrijednost od 20% trajanja faze odnosno trajanja pojma zelenog svjetla. Minimalno trajanje faze iznosi 80% trajanja u fiksnom planu, a maksimalno trajanje iznosi 120% trajanja u fiksnom planu. Prema tome parametar KPT iznosi 0, 20. Iz toga se dobiva da minimalno trajanje ciklusa iznosi 75 [s], a maksimalno trajanje 105 [s]. Za iznos vremena za koji se produljuje trajanje faze (ΔT) koristeći MKO odabrano je 2 [s] kao sredina određena sredina između vrijednosti koje se koriste u SCOOT sustavu [13]. Ove vrijednosti su izabrane koristeći preporuke iz literature [11] [12] [13] te umjeravanjem upravljačkog sustava metodom pokušaja i pogreške kako bi se postigli što bolji rezultati.

6.2 Opis prometnih scenarija

Za testiranje predloženih metoda konstruirana su tri prometna scenarija s različitim prometnim potražnjama. Prometni podaci korišteni za stvaranje scenarija preuzeti su iz [32] i predstavljaju stvarnu prometnu potražnju dobivenu brojanjem prometa. U tablici 3 su prikazani prometni scenariji s odgovarajućim prometnim opterećenjima. Opterećenje u scenariju 2 je zadržano kao i u [32], a scenarij 1 je predstavlja to isto opterećenje umanjeno za 40% kako bi se simulirala smanjena potražnja, a scenarij 3 to isto opterećenje uvećano za 40% kako bi se simulirala povećana potražnja i zagušenje.

Tablica 3: PROMETNA POTRAŽNJA SVAKOG SCENARIJA

Scenarij	Prometna potražnja [voz/h]			
	Privoz			
	Istočni	Sjeverni	Zapadni	Južni
1	660	132	432	90
2	1.100	220	720	150
3	1.540	308	1.008	210

6.3 Prikaz i analiza rezultata


Za potrebe izvođenja evaluacije rada predloženih metoda ukupno je izvršeno 120 simulacija, za svaki prometni scenarij po 30, uključujući i fiksni signalni plan. U tih 30 simulacija ih je po deset izvršeno za dobivanje rezultata djelovanja fiksnog upravljanja, metode odlučivanja na početku faze i metode kontinuiranog odlučivanja. Trajanje pojedine simulacije iznosi 4.500 [s] odnosno jedan sat i petnaest minuta, od kojih se prvih 900 [s] (15 minuta) izuzima iz rezultata jer je korišteno za punjenje prometne mreže i početno računanje prometnog volumena. Iz VISSIM-a su tijekom simulacije preuzeti sljedeći prometni parametri koji opisuju rad predloženih metoda:

1. Prosječna duljina repa čekanja;
2. Najveća dostignuta duljina repa čekanja;
3. Broj stajanja vozila;
4. Vrijeme putovanja vozila;
5. Emisije ispušnih plinova.

6.3.1 Rezultati prvog scenarija


Prema parametrima prvog scenarija iznosi prosječnih duljina repova čekanja su prikazani u grafikonu 1. Iz grafikona je vidljivo smanjenje repova čekanja kod obje metode naspram fiksnog upravljanja. S fiksnim upravljanjem ukupan iznos prosječnih repova čekanja sva četiri privoza iznosi 28 [m]. Primjenom MOP ta vrijednost iznosi 26,7 [m],

odnosno postoji poboljšanje u iznosu od 5%. Primjenom MKO ta vrijednost iznosi 24,7 [m] te postignuto poboljšanje iznosi 12%.




Grafikon 1: Prosječne vrijednosti repova čekanja - scenarij 1

Iz grafikona 2 je vidljivo smanjenje maksimalnih repova čekanja kod obje metode zasnovane na neizrazitoj logici naspram fiksnog upravljanja. S fiksnim upravljanjem ukupan iznos maksimalnih repova čekanja sva četiri privoza iznosi 220,8 [m]. Primjenom MOP ta vrijednost iznosi 196,4 [m], odnosno postoji poboljšanje u iznosu 11%. Primjenom MKO ta vrijednost iznosi 197,0 [m] te postignuto poboljšanje iznosi 11%.




Grafikon 2: Prosječne vrijednosti maksimalnih repova čekanja - scenarij 1

Grafikon 3 prikazuje broj stajanja (zaustavljanja) vozila po privozima. S fiksnim upravljanjem ukupan iznos prosječnog broja stajanja sva četiri privoza iznosi 848. Primjenom MOP ta vrijednost iznosi 848, što donosi razliku od jednog stajanja, odnosno nema utjecaja. Primjenom MKO ta vrijednost iznosi 867 te je postignuto pogoršanje naspram fiksnog upravljanja u iznosu od 2%.



Grafikon 3: Prosječni broj stajanja vozila - scenarij 1




Grafikon 4: Prosječne vrijednosti vremena putovanja - scenarij 1

Grafikon 4 prikazuje prosječno vrijeme putovanja vozila kroz svih 10 simulacija. Iz grafikona je vidljivo da se primjenom objih metoda zasnovanih na neizraveznoj logici postižu

bolji rezultati odnosno brži prolazak vozila kroz mrežu. Primjenom fiksnog upravljanja prosječno vrijeme putovanja kroz mrežu iznosi 33,6 [s]. Koristeći MOP prosječno vrijeme putovanja iznosi 32,6 [s] što predstavlja poboljšanje u iznosu od 3% naspram fiksnog upravljanja. U slučaju primjene MKO, prosječno vrijeme putovanja iznosi 31,7 [s] što je za 6% bolje od fiksnog upravljanja. U tablici 4 dane su vrijednosti prosječne količine emisija štetnih plinova kroz svih 10 simulacija. Koristeći obje metode nije postignuto poboljšanje niti značajno pogoršanje. Na grafikonu 5 bok uz bok su prikazana trajanja ciklusa koristeći MOP i MKO. Prikazano je 20 ciklusa simulacije broj 8 pri čemu je s lijeve strane su prikazane duljine ciklusa dobivene s MOP, a s desne dobivene s MKO. U toj simulaciji je izvršeno 53 ciklusa koristeći MOP s prosječnim trajanjem od 87 [s]. Koristeći MKO izvršilo se 61 ciklusa s prosječnim trajanjem od 75 [s].

Tablica 4: PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 1


	Fiksno upravljanje	MOP		MKO	
		Iznos	Poboljšanje [%]	Iznos	Poboljšanje [%]
CO_2 [g]	124.160	124.140	0	124.740	0
NO_X [g]	685	682,9	0	682,8	0
PM_{10} [g]	79	78,9	0	79,3	0



Grafikon 5: Odbраниh 20 ciklusa simulacije 8 - scenarij 1: (a) koristeći MOP, (b) koristeći MKO


6.3.2 Rezultati drugog scenarija

Prema parametrima drugog scenarija iznosi prosječnih duljina repova čekanja su prikazani u grafikonu 6. Iz grafikona je vidljivo smanjenje repova čekanja kod obje metode naspram fiksnog upravljanja osim na sjevernom i južnom privozu gdje je metoda MOP uzrokovala duže repove. Sa fiksnim upravljanjem ukupan iznos prosječnih repova čekanja sva četiri privoza iznosi 58,3 [m]. Primjenom MOP ta vrijednost iznosi 56,7 [m], odnosno postoji poboljšanje u iznosu 3%. Primjenom MKO ta vrijednost iznosi 53,8 [m] te postignuto poboljšanje iznosi 8%.




Grafikon 6: Prosječne vrijednosti repova čekanja - scenarij 2

Iz grafikona 7 je vidljivo smanjenje maksimalnih repova čekanja kod obje metode naspram fiksnog upravljanja osim kod korištenja MOP na sjevernom privozu. Kod fiksnog upravljanja ukupan iznos maksimalnih repova čekanja sva četiri privoza iznosi 326,8 [m]. Primjenom MOP ta vrijednost iznosi 329,0 [m], odnosno postoji pogoršanje u iznosu 1%. Primjenom MKO ta vrijednost iznosi 312 [m] te postignuto poboljšanje iznosi 5%. Grafikon 8 prikazuje broj stajanja vozila po privozima. Sa fiksnim upravljanjem ukupan iznos prosječnog broja stajanja sva četiri privoza iznosi 1.652. Primjenom MOP ta vrijednost iznosi 1.637 što je približno 1% bolje od fiksnog upravljanja. Primjenom MKO ta vrijednost iznosi 1.712 te je postignuto pogoršanje naspram fiksnog upravljanja u iznosu od 4%.




Grafikon 7: Prosječne vrijednosti maksimalnih repova čekanja - scenarij 2



Grafikon 8: Prosječni broj stajanja vozila - scenarij 2

Grafikon 9 prikazuje prosječno vrijeme putovanja vozila kroz svih 10 simulacija. Primjenom fiksnog upravljanja prosječno vrijeme putovanja kroz mrežu iznosi 36,6 [s]. Koristeći MOP prosječno vrijeme putovanja iznosi 36,9 [s] što predstavlja pogoršanje od približno 1% naspram fiksnog upravljanja. U slučaju primjene MKO, prosječno vrijeme putovanja iznosi 35,5 [s] što je za 3% bolje od fiksnog upravljanja. U tablici 5 dane su vrijednosti prosječne količine emisija štetnih plinova kroz svih 10 simulacija. Koristeći MOP dobiveno je ili poboljšanje u iznosu od 1% ili nikakvo poboljšanje. Koristeći MKO

dobiveno je pogoršanje u iznosu -1% naspram fiksnog signalnog plana za sve promatrane ispušne plinove.




Grafikon 9: Prosječne vrijednosti vremena putovanja - scenarij 2

Tablica 5: PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 2

	Fiksno upravljanje	MOP		MKO	
		Iznos	Poboljšanje [%]	Iznos	Poboljšanje [%]
CO_2 [g]	222.730	221.680	0	224.880	-1
NO_X [g]	1.223, 4	1.216, 9	1	1.230, 3	-1
PM_{10} [g]	143, 2	142, 4	1	144, 5	-1


Na grafikonu 10 bok uz bok su prikazana trajanja ciklusa koristeći MOP i MKO. Prikazano je 20 ciklusa simulacije broj 8 pri čemu je s lijeve strane su prikazane duljine ciklusa dobivene s MOP, a s desne dobivene s MKO. U toj simulaciji je izvršeno 51 ciklusa koristeći MOP s prosječnim trajanjem od 89 [s]. Koristeći MKO izvršilo se 61 ciklusa s prosječnim trajanjem od 75 [s].



Grafikon 10: Odabranih 20 ciklusa simulacije 8 - scenarij 2: (a) koristeći MOP, (b) koristeći MKO


6.3.3 Rezultati trećeg scenarija

Prema parametrima trećeg scenarij iznosi prosječnih duljina repova čekanja su prikazani u grafikonu 11. Iz grafikona je vidljivo smanjenje repova čekanja kod obje metode naspram fiksnog upravljanja za privoze glavnog sporednog toka, te malo pogoršanje na privozima sporednog toka. S fiksnim upravljanjem ukupan iznos prosječnih repova čekanja sva četiri privoza iznosi 331, 2 [m]. Primjenom MOP ta vrijednost iznosi 233, 0 [m], odnosno postoji poboljšanje u iznosu 30%. Primjenom MKO ta vrijednost iznosi 235, 8 [m] te postignuto poboljšanje iznosi 29%.




Grafikon 11: Prosječne vrijednosti repova čekanja - scenarij 3

Iz grafikona 12 je vidljiva gotovo nikakva razlika u maksimalnim duljinama repova čekanja. Sa fiksnim upravljanjem ukupan iznos maksimalnih repova čekanja sva četiri privoza iznosi 553,2 [m]. Primjenom MOP ta vrijednost iznosi 551,5 [m] što je razlika za samo 1,7 [m] manje od fiksnog upravljanja. Primjenom MKO ta vrijednost iznosi 553,1 [m] te je razlika u odnosu na fiksno upravljanje gotovo nepostojeća.




Grafikon 12: Prosječne vrijednosti maksimalnih repova čekanja - scenarij 3

Grafikon 13 prikazuje broj stajanja vozila po privozima. Vidljiv je značajno manji broj stajanja kod privoza glavnog prometnog toka te malo pogoršanje kod privoza sporednog toka. S fiksnim upravljanjem ukupan iznos prosječnog broja stajanja sva četiri privoza iznosi 5.745. Primjenom MOP ta vrijednost iznosi 4.521 što je 21% bolje od fiksnog upravljanja. Primjenom MKO ta vrijednost iznosi 4.947 te je postignuto poboljšanje u iznosu od 14% naspram fiksnog upravljanja.



Grafikon 13: Prosječni broj stajanja vozila - scenarij 3

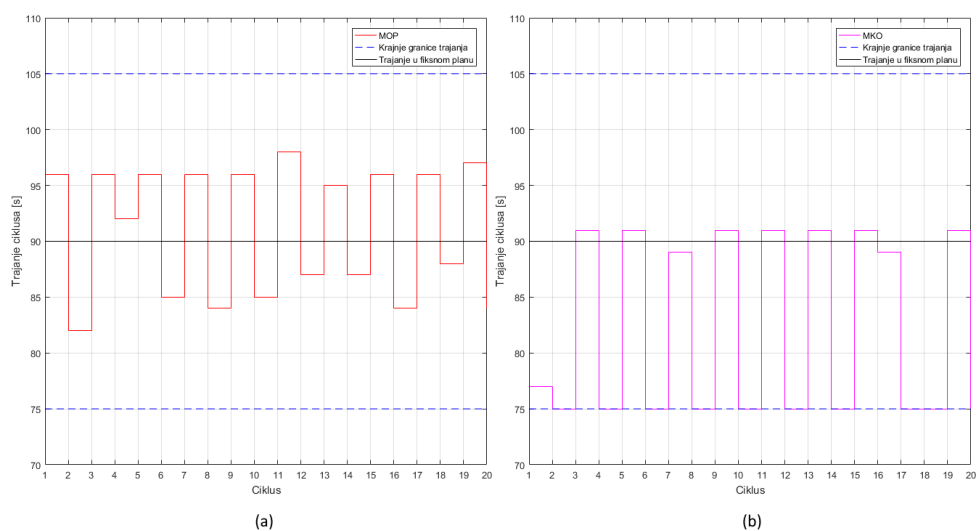
Grafikon 14 prikazuje prosječno vrijeme putovanja vozila kroz svih 10 simulacija. Primjenom fiksnog upravljanja prosječno vrijeme putovanja kroz mrežu iznosi 95,0 [s]. Koristeći MOP prosječno vrijeme putovanja iznosi 71,7 [s] što predstavlja poboljšanje u iznosu od 24% naspram fiksnog upravljanja. U slučaju primjene MKO, prosječno vrijeme putovanja iznosi 70,5 [s] što je za 26% bolje od fiksnog upravljanja. U tablici 6 dane su vrijednosti prosječne količine emisija štetnih plinova kroz svih 10 simulacija. Koristeći MOP sve emisije štetnih plinova su smanjene za najmanje 10%. Koristeći MKO su rezultati malo lošiji od korištenja prijašnje metode, ali su i dalje bolji od fiksnog upravljanja. Na grafikonu 15 bok uz bok su prikazana trajanja ciklusa koristeći MOP i MKO. Prikazano je 20 ciklusa simulacije broj 8 pri čemu je s lijeve strane su prikazane duljine ciklusa dobivene s MOP, a s desne dobivene s MKO. U toj simulaciji je izvršeno 48 ciklusa koristeći MOP s prosječnim trajanjem od 92 [s]. Koristeći MKO izvršilo se 55 ciklusa s prosječnim trajanjem od 79 [s].



Grafikon 14: Prosječne vrijednosti vremena putovanja - scenarij 3

Tablica 6: PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 3

	Fiksno upravljanje	MOP		MKO	
		Iznos	Poboljšanje [%]	Iznos	Poboljšanje [%]
CO_2 [g]	478.550	430.420	10	440.800	8
NO_X [g]	2.901,1	2.502	14	2.534,4	13
PM_{10} [g]	325,5	287,8	12	295,2	9



Grafikon 15: Odabranih 20 ciklusa simulacije 8 - scenarij 3: (a) koristeći MOP, (b) koristeći MKO

6.3.4 Analiza rezultata

U scenariju umanjene prometne potražnje obje metode su postigle smanjenje repova čekanja, MOP 5%, a MKO 12%. Koristeći MOP izvršeno je manje u prosjeku dužih ciklusa, a koristeći MKO više kraćih. Prosječno trajanje ciklusa kod obje metode je bilo kraće nego kod fiksnog upravljanja. Do toga je došlo jer MKO odgovara trenutnim potrebama signalnih grupa, dok MOP donosi odluku bez znanja stanja na prometnici u trenutku produljenja. Osim smanjenja repova čekanja, obje metode su rezultirale i kraćim prosječnim vremenom putovanja kao što je prikazano u tablici 7. U drugu ruku, kraće prosječno trajanje ciklusa kod obje metode izazvalo je povećanje broja stajanja vozila zbog češćih izmjena faza te zbog toga nije došlo do smanjenja emisija štetnih plinova.

Tablica 7: PROSJEČNE VRIJEDNOSTI VREMENA PUTOVANJA SVIH SCENARIJA

Scenarij	Fiksno upravljanje [s]	MOP		MKO	
		Iznos [s]	Poboljšanje [%]	Iznos [s]	Poboljšanje [%]
1	33,6	32,6	3	31,7	6
2	36,6	36,9	−1	35,5	3
3	95,0	71,7	24	70,5	26

U scenariju srednje prometne potražnje obje su metode rezultirale podjednako te ne mnogo drugačije od fiksnog upravljanja. Prosječno trajanje ciklusa kod MOP bilo je 89 [s] što je za jednu sekundu manje od trajanja ciklusa kod fiksnog upravljanja, a kod MKO je prosječno trajanje ciklusa iznosilo 75 [s] što je ujedno i minimalno moguće trajanje ciklusa. Najveće poboljšanje je dobiveno koristeći MKO kada se promatraju prosječne duljine repova čekanja gdje je to poboljšanje iznosilo 8%. Prosječno vrijeme putovanja prikazano u tablici 7 pokazuje malenu promjenu koristeći obje metode u odnosu na fiksno upravljanje.

U scenariju povećane prometne potražnje postignuta su značajna poboljšanja prosječnih duljina repova čekanja, 30% koristeći MOP i 29% koristeći MKO. Prosječno trajanje ciklusa je iznosilo 2 [s] više kod MOP i 11 [s] manje kod MKO u odnosu na fiksno upravljanje. Broj stajanja se također smanjio kod obje metode što je rezultiralo smanjenju emisija štetnih plinova te značajno kraćem prosječnom vremenu putovanja kao što je vidljivo u tablici 7. MOP se pokazala kao bolja metoda za promjenu trajanja faze te je ostvarila bolje rezultate kod svih promatranih parametara osim kod vremena putovanja koje je bilo

lošije nego kod MKO za 1, 2 [s]. Na slici 15 vidljive su velike oscilacije u trajanju ciklusa kod obje metode upravljanja. Takvo ponašanje jest nedostatak sustava te bi se blažim prijelazima između trajanja ciklusa postiglo uravnoteženije upravljanje prometom.

Obje metode su se pokazale kao unaprijeđenje naspram fiksnog upravljanja nad promatranim raskrižjem. Zbog postavka sustava upravljanja u oba slučaja je prednost dana glavnom prometnom toku što je rezultiralo većim poboljšanjem kada se gledaju ukupni rezultati. U prvom i drugom scenariju najboljom se pokazala metoda kontinuiranog odlučivanja, a u trećem scenariju metoda odlučivanja na početku izvršavanja ciklusa.

7 Zaključak

Primjenom ITS upravljačkih rješenja kod semaforiziranih raskrižja postižu se pozitivni učinci. U ovom završnom radu je dano jedno takvo rješenje. Implementirana su dvije metode odlučivanja o promjeni trajanja faze zasnovana na neizrazitoj logici, MOP i MKO. Princip rada tih metoda je donošenje odluke o tome za koliko produljiti trenutnu fazu zelenog svjetla na osnovi trenutnog stanja na prometnici. Ocjenu stanja na prometnici donosi neizrazita logika. Ovaj sustav odlučivanja odnosno upravljanja je implementiran koristeći MATLAB i VISSIM kao potporu jedno drugome. Navedene metode su analizirane pomoću podataka dobivenih simulirajući izolirano dvofazno raskrižje u odnosu na fiksno upravljanje koristeći tri različita prometna scenarija. Prometni scenariji se razlikuju po količini prometne potražnje od slobodnog do zagušenog prometnog toka.

Iz dobivenih rezultata vidljivo je da je primjenom neizrazite logike moguće poboljšati upravljanje semaforiziranim raskrižjima. Obje metode su se pokazale kao bolje opcije od korištenja fiksnog upravljanja. Kvaliteta upravljanja značajno ovisi o odabranim funkcijama pripadnosti i definiranim pravilima zaključivanja. Nastavak istraživanja vidi se u davanju više fokusa scenarijima umanjene i srednje potražnje kroz dodatnu analizu rada upravljačkog sustava te podešavanju pravila odlučivanja kako bi se ublažile velike oscilacije trajanja ciklusa nastale u scenariju povećane prometne potražnje. Također se predlaže korištenje algoritama strojnog učenja u vidu optimiranja parametara neizrazitog sustava odlučivanja tijekom njegovog rada.

Literatura

- [1] Wiesenhal D Hennessy D. Traffic congestion, driver stress, and driver aggression. 25:409 – 423, 1999.
- [2] Golubić J. "Promet i okoliš". Fakultet prometnih znanosti, Zagreb, 1999.
- [3] Mandžuka S. "Inteligentni transportni sustavi 1 - Inteligentno upravljanje prometom", predavanja. Fakultet prometnih znanosti, Zagreb, 2007.
- [4] Anžek M, Divić A, Lanović Z. Smjernice za prometnu svjetlosnu signalizaciju na cestama. Ministarstvo pomorstva, prometa i veza, Zagreb, 2001.
- [5] Vujić M. "Cestovna telematika - Osnovni pojmovi iz područja cestovne telematike", predavanja. Fakultet prometnih znanosti, Zagreb, 2017.
- [6] Vujić M. "Cestovna telematika - Strategije i taktike upravljanja prometom", predavanja. Fakultet prometnih znanosti, Zagreb, 2017.
- [7] Vidaković F. Koncept razvoja centra za nadzor i upravljanje prometom u gradovima. Diplomski rad, Fakultet prometnih znanosti, Zagreb, 2017.
- [8] Mathew TV. Transportation Systems Engineering - Vehicle Actuated Signals - predavanje. Indian Institute of Technology, Bombay, 2014.
- [9] Bošnjak I. "Inteligentni transportni sustavi 1". Sveučilište u Zagrebu, Fakultet prometnih znanosti, Zagreb, 2006.
- [10] Samadi S, Rad AP, Kazemi FM, Jafarian H. Performance Evaluation of Intelligent Adaptive Traffic Control Systems: A Case Study. *Journal of Transportation Technologies*, 2(10):248–259, 2012.
- [11] Highway Capacity Manual - HCM2000. Transportation Research Board of the National Academies, 2010.
- [12] Ngan VWK. A comprehensive strategy for transit signal priority. Diplomski rad, University of British Columbia, Vancouver, Canada, Listopad 2002.

- [13] SCOOT USER GUIDE. Siemens Mobility, Traffic Solutions UTC System, 2016.
- [14] Zadeh LA. Fuzzy Sets. *Information and control*, 8:338–353, 1965.
- [15] Mamdani EH, Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7:1–13, 1975.
- [16] Pappis CP, Mamdani EH. A Fuzzy Logic Controller for a Traffic Junction. *IEEE Transactions on Systems, Man, and Cybernetics*, 7:707–717, 1977.
- [17] Trabia MB, Kaseko MS, Ande M. A two stage fuzzy logic controller for traffic signals. *Transportation Research Part C*, 7:353–367, 1999.
- [18] Murat YS, Gedizlioglu E. A fuzzy logic multi-phased signal control model for isolated junctions. *Transportation Research Part C*, 13:19–36, 2005.
- [19] Nair BM, Cai J. A Fuzzy Logic Controller for Isolated Signalized Intersection with Traffic Abnormality Considered. *2007 IEEE Intelligent Vehicles Symposium*, 2017.
- [20] Chiou YC, Lan LW. Adaptive traffic signal control with iterative genetic fuzzy logic controller (GFLC). *IEEE International Conference on Networking, Sensing and Control, 2004*, 2004.
- [21] Qiao J, Yang N, Gao J. Two-Stage Fuzzy Logic Controller for Signalized Intersection. *Systems, Man and Cybernetics, Part A: Systems and Humans, IEEE Transactions on*, 41:178 – 184, 02 2011.
- [22] Wei W, Zhang Y. FL-FN based traffic signal control. *2002 IEEE World Congress on Computational Intelligence. 2002 IEEE International Conference on Fuzzy Systems. FUZZ-IEEE'02. Proceedings (Cat. No.02CH37291)*, 1:296–300, 2002.
- [23] Niittymäki J, Kikuchi S. Application of Fuzzy Logic to the Control of a Pedestrian Crossing Signal. *Transportation Research Record*, 1651:30–38, 01 1998.
- [24] Hurwitz DS, Wang H, Knodler MA, Ni D, Moore D. Fuzzy sets to describe driver behavior in the dilemma zone of high-speed signalized intersections. *Transportation Research Part F: Traffic Psychology and Behaviour*, 15(2):132–143, 2012.

- [25] Vogel A, Oremović I, Šimić R, Ivanjko E. Improving traffic light control by means of fuzzy logic. Prihaćeno za prezentaciju na 60th International Symposium ELMAR-2018, Zadar, Hrvatska, 2018.
- [26] Pregled programskog paketa MATLAB. Preuzeto sa: <https://www.mathworks.com/videos/matlab-overview-61923.html> [Pristupljeno: kolovoz 2018.].
- [27] Ban Ž, Matuško J, Petrović I. *Primjena programskog sustava MATLAB za rješavanje tehničkih problema*. Zagreb: GRAPHIS, 2010.
- [28] Korent N. Usporedba algoritama za upravljanje promjenjivim ograničenjem brzine na urbanim autocestama. Diplomski rad, Fakultet prometnih znanosti, Zagreb, 2017.
- [29] Kapusta B. Simulacija prioritetnih prolaska vozila žurne službe kroz semaforizirano raskrižje. Završni rad, Fakultet prometnih znanosti, Zagreb, 2017.
- [30] Microsoft COM Technical Overview. Preuzeto sa: <https://docs.microsoft.com/en-us/windows/desktop/com/com-technical-overview> [Pristupljeno: kolovoz 2018.].
- [31] EnViVer: model traffic flow and emissions. Preuzeto sa: <https://www.tno.nl/en/focus-areas/traffic-transport/roadmaps/automotive-research-at-tno/clean-mobility/enviver-model-traffic-flow-and-emissions/> [Pristupljeno: kolovoz 2018.].
- [32] Vujić M. Sustav dinamičkih prioriteta za vozila javnog gradskog prijevoza u automat-skom upravljanju prometom. Doktorska disertacija, Fakultet Prometnih Znanosti, Sveučilište u Zagrebu, 2013.

Popis slika

1	Prikaz produljivanja faze - MOP	8
2	Prikaz produljivanja faze - MKO	9
3	Prikaz funkcija pripadnosti temperature	11
4	Prikaz funkcija pripadnosti repa čekanja	15
5	Prikaz funkcija pripadnosti hitnosti	17
6	Dijagram toka izvođenja simulacije korištenjem MKO	19
7	Shematski prikaz simulacijskog okruženja	20
8	Prikaz grafičkog sučelja mikroskopskog simulatora PTV VISSIM	22
9	Signalni plan promatranog raskrižja	24
10	Prikaz modela raskrižja i razmještaj detektora	25

Popis tablica

1	PRIMJER NEIZRAZITIH PRAVILA U UPRAVLJANJU SUSTAVOM VENTILACIJE	12
2	IZVADAK NEIZRAZITIH PRAVILA 17.-32.	16
3	PROMETNA POTRAŽNJA SVAKOG SCENARIJA	26
4	PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 1 . . .	29
5	PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 2 . . .	32
6	PROSJEČNE VRIJEDNOSTI EMISIJA ŠTETNIH PLINOVA - SCENARIJ 3 . . .	36
7	PROSJEČNE VRIJEDNOSTI VREMENA PUTOVANJA SVIH SCENARIJA	37

Popis grafikona

1	Prosječne vrijednosti repova čekanja - scenarij 1	27
2	Prosječne vrijednosti maksimalnih repova čekanja - scenarij 1	27
3	Prosječni broj stajanja vozila - scenarij 1	28
4	Prosječne vrijednosti vremena putovanja - scenarij 1	28
5	Odabranih 20 ciklusa simulacije 8 - scenarij 1: (a) koristeći MOP, (b) koristeći MKO	29
6	Prosječne vrijednosti repova čekanja - scenarij 2	30
7	Prosječne vrijednosti maksimalnih repova čekanja - scenarij 2	31
8	Prosječni broj stajanja vozila - scenarij 2	31
9	Prosječne vrijednosti vremena putovanja - scenarij 2	32
10	Odabranih 20 ciklusa simulacije 8 - scenarij 2: (a) koristeći MOP, (b) koristeći MKO	33
11	Prosječne vrijednosti repova čekanja - scenarij 3	34
12	Prosječne vrijednosti maksimalnih repova čekanja - scenarij 3	34
13	Prosječni broj stajanja vozila - scenarij 3	35
14	Prosječne vrijednosti vremena putovanja - scenarij 3	36
15	Odabranih 20 ciklusa simulacije 8 - scenarij 3: (a) koristeći MOP, (b) koristeći MKO	36



Sveučilište u Zagrebu
Fakultet prometnih znanosti
10000 Zagreb
Vukelićeva 4

IZJAVA O AKADEMSKOJ ČESTITOSTI I SUGLASNOST

Izjavljujem i svojim potpisom potvrđujem kako je ovaj _____ završni rad

isključivo rezultat mog vlastitog rada koji se temelji na mojim istraživanjima i oslanja se na objavljenu literaturu što pokazuju korištene bilješke i bibliografija.

Izjavljujem kako nijedan dio rada nije napisan na nedozvoljen način, niti je prepisan iz necitiranog rada, te nijedan dio rada ne krši bilo čija autorska prava.

Izjavljujem također, kako nijedan dio rada nije iskorišten za bilo koji drugi rad u bilo kojoj drugoj visokoškolskoj, znanstvenoj ili obrazovnoj ustanovi.

Svojim potpisom potvrđujem i dajem suglasnost za javnu objavu _____ završnog rada

pod naslovom **MOGUĆNOSTI PRIMJENE NEIZRAZITE LOGIKE ZA ODREĐIVANJE**

PRODULJENJA VREMENA POJEDINE FAZE KOD SEMAFORIZIRANIH RASKRIŽJA

na internetskim stranicama i repozitoriju Fakulteta prometnih znanosti, Digitalnom akademskom repozitoriju (DAR) pri Nacionalnoj i sveučilišnoj knjižnici u Zagrebu.

Student/ica:

U Zagrebu, 9.9.2018

(potpis)